

基于 OD-LTP 的振动条件下串联型故障电弧检测方法研究*

刘艳丽 张凌玮 吕正阳 王家林

(辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

摘要:当三相异步电动机发生机械振动时,主回路中接触不良的电气接触点在振动作用下会产生串联型故障电弧,进而影响电路安全甚至引发电气火灾。而振动条件会加剧了故障电弧信号的复杂性,因此本文以回路电流信号为研究对象,提出了一种振动条件下的高实时性串联型故障电弧检测方法。首先通过构建滑动记忆矩阵对实验电流数据进行动态保存,其次通过正交方向改进局部三值化模式(orthogonality direction local ternary pattern, OD-LTP)提取滑动记忆矩阵的纹理特征,最终将统计的 OD-LTP 图像的灰度分布直方图幅值作为特征向量,通过基于沙猫群优化(sand cat swarm optimization, SCSO)的支持向量机(support vector machine, SVM)建立振动串联型故障电弧检测模型。本文通过对比不同矩阵参数,得到最佳的滑动记忆矩阵尺寸,最终所提方法对故障电弧识别的准确率达到 99.2%。通过对不同工况、不同特征提取方法对比分析,表明本文提出方法不仅适用于不同工况运行的工业电机变频器系统,其相对于其他特征提取方法也具有更高的实时性。

关键词:串联型故障电弧;滑动记忆矩阵;OD-LTP;SCSO-SVM;快速性

中图分类号: TM501.2; TN911.73

文献标识码: A

国家标准学科分类代码: 510.40

Study on the detection method of series fault arc under vibration condition based on OD-LTP

Liu Yanli Zhang Lingwei Lyu Zhengyang Wang Jialin

(Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract: When mechanical vibration occurs in a three-phase asynchronous motor, the poor electrical contact points in the main circuit will generate a series of fault arcs under the influence of vibration, which will compromise circuit safety and potentially lead to electrical fires. The vibration condition complicates the fault arc signal, so this paper proposes a highly real-time series fault arc detection method under vibration conditions. First, experimental current data is dynamically preserved by constructing a sliding memory matrix. Secondly, the texture features of the sliding memory matrix are extracted using orthogonality direction local ternary pattern (OD-LTP). Finally, the amplitude of the grayscale distribution histogram of the statistical OD-LTP images is taken as the feature vector. A vibrating series fault arc detection model is established using support vector machine (SVM) optimized by sand cat swarm optimization (SCSO). By comparing different matrix parameters, the proposed method achieves an accuracy of 99.2%. Through a comparative analysis of different feature extraction methods under various working conditions, it is shown that the proposed method is not only suitable for industrial motor inverter systems under different working conditions, but also exhibits higher real-time performance compared to other feature extraction methods.

Keywords: series fault arc; sliding memory matrix; OD-LTP; SCSO-SVM; rapidity

0 引言

在实际生产中,三相异步电动机产生机械振动的原

因主要有 3 种,分别是电动机动平衡不好、轴承不良、转轴弯曲等机械故障;电动机安装基础不平、紧固件松动等安装问题;以及机械负载端振动传递、传动装置安装不良等外界原因。当三相异步电动机产生机械振动导致电气

接触点松动时,电气接触点会在振动作用下产生串联故障电弧。串联型故障电弧不仅会增加电动机的能耗,使其更易损坏,甚至还可能引发电气火灾。由于串联型故障电弧具有随机性、隐蔽性等特点,加之接触点振动使其信号特征复杂化,因此研究三相电动机负载振动条件下串联型故障电弧的检测问题是非常必要的。

近年来,关于串联故障电弧研究多聚焦于提取回路电流信号特征方法,并探索了多种特征提取思路。部分研究者利用原始电流信号的时域特性提取特征,例如文献[1]计算电流信号的脉冲因子进行故障电弧初步识别,文献[2]根据信号类型枚举方法结合分类算法实现家庭单负载电路串联型故障电弧检测。同时,采用时频域分析方法也是研究者的另一主要研究思路。部分研究者在时域、频域的基础上结合时频域分析方法如小波包能量谱等构建特征集^[3]。还有研究者通过变分模态分解^[4]、经验模态分解^[5]及融合自适应噪声的完备经验模态分解^[6]等改进模态分解方法对电流信号进行分解,并提取高频分量的信号特征构建特征集。

除了传统的分解方法,一些研究者尝试将一维电流信号转换为多维矩阵进行处理。文献[7]将半周期电流信号时间序列排布成二维矩阵后,利用自归一化卷积神经网络实现低压串联故障电弧识别。文献[8]提出了使用双树复小波变换结合改进的奇异值分解的特征提取方法。文献[9]利用无阈递归图结合灰度共生矩阵方法处理电流信号,并提取 21 个矩阵参数特征作为串联故障电弧特征。这些方法将信号处理与图像处理相结合,为电流特征提取提供了新的视角。除此之外,一些研究者基于深度学习算法如全连接神经网络^[10]来构建关于电流波形的检测模型。

上述特征提取思路集中研究光伏直流、航空交流以及家庭低压配电系统,并未涉及工业系统电动机带变频器负载的串联故障电弧检测问题,目前相关学者针对该问题进行了以下一系列研究。文献[11]利用循环神经网络对干路电流进行检测实现多电机负载电路的串联故障电弧检测和选线。文献[12]利用核主成分分析提取故障相电流与电源电压的第五、六主元的峰度和偏度作为特征,利用萤火虫算法优化(firefly algorithm,FA)的支持向量机(support vector machines,SVM)实现了复杂谐波下串联型故障电弧检测。文献[13]使用变分模态分解对单相电流信号分解后,提取分量的样本熵与能量熵作为特征,通过 FA-SVM 实现对电机变频器负载的串联故障电弧检测。文献[14]对故障相电流差分信号使用小波包分解重构成矩阵,并将其灰度-梯度共生矩阵的 15 个特征量作为故障特征。文献[15]通过分数阶傅里叶变换和奇异值分解提取电流信号特征,借助网格搜索(grid search,GS)和粒子群优化算法(particle swarm

optimization,PSO)优化的 SVM 实现了电机变频器负载电弧故障检测和相位选择。文献[16]对故障相电流信号进行 5 层经验小波分解后构成信号延迟矩阵并利用奇异值分解提取矩阵特征,通过 GS-PSO-SVM 实现了串联型故障电弧的识别。文献[17]基于逐点等距映射将电流信号重建为矩阵,通过轻量化卷积神经网络建立故障电弧分类识别模型,并在嵌入式设备上实现了在线检测。

上述研究工作促进了三相异步电动机电路系统中串联型故障电弧检测技术的发展,但在文献[12-17]中忽视了变频器后端故障电弧及振动条件对电流波形的影响。为了解决这一问题,本文研究了工业电机变频器负载电路在振动条件下串联型故障电弧快速检测方法。本文的主要学术贡献和创新内容如下:

1) 提出了一种滑窗记忆矩阵方法动态保存电流数据,并通过对比分析找到最佳矩阵尺寸,减少识别所需数据量,提高振动串联故障电弧检测的实时性。

2) 设计一种正交方向改进局部三值化模式(orthogonality direction local ternary pattern,OD-LTP)提取滑窗记忆矩阵纹理特征,为实现检测模型的快速性创造了条件。

3) 通过在不同工况下进行实验验证,证明了本文方法在不同工况下串联型故障电弧检测的通用性;通过对比不同特征提取方法,证明所提算法具有准确性高、实时性好的特点。

1 电机变频器负载串联型故障电弧实验

1.1 实验平台介绍

本文搭建了振动条件下三相异步电动机变频器负载串联型故障电弧实验平台。实验电路分别由主电路、信号采集电路以及电弧发生装置三部分组成,实验系统整体结构如图 1 所示。主电路使用三相 AC 380 V 作为电源,使用带 VFD110E43A 型变频器的 Y160M-6-11KW 三相异步电动机作为负载,通过磁粉制动器调节三相异步电动机的负载电流。本文在变频器与三相异步电动机间串联电弧发生装置,并通过信号采集电路采集电流数据。信号采集电路由 $DC \pm 15\text{ V}$ 电源供电,使用 LHB100A5VY2 型电流传感器采集回路电流信号,并使用 USB3200 型数据采集卡将采集的电流数据上传至计算机中,在 LabVIEW 软件中进行显示。

振动故障电弧发生器如图 2 所示,通过音圈电机带动移动电极做往复运动,模拟接触不良的电气接触点在电动机发生机械振动时接触点的振动情况,并实现振动参数的精确控制。设备使用 $DC \pm 24\text{ V}$ 开关电源为振动故障电弧发生器供电,使用 Comply 音圈电机控制器通过电流信号与来自光栅传感器的位置信号对音圈电机进

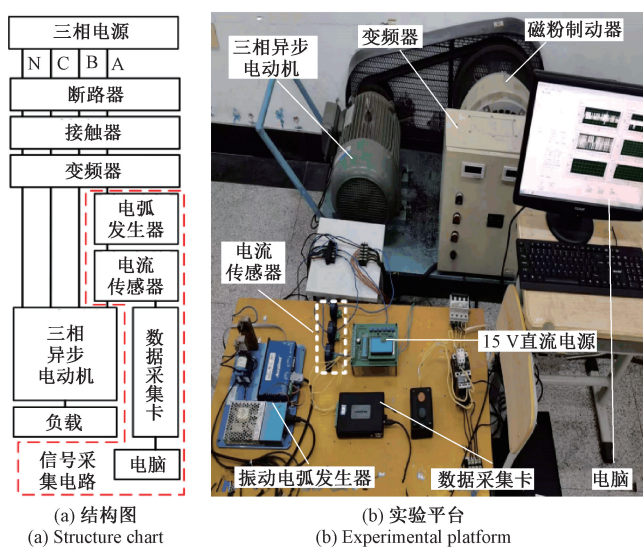


图 1 实验系统图

Fig. 1 Experimental system diagram

行控制,并在计算机中通过 CME 软件完成振动参数的具体设置,以及振动的启动和停止,各部分参数如表 1 所示。




图 2 振动故障电弧发生器

Fig. 2 Vibration fault arc generator

表 1 振动电弧发生器设备参数

Table 1 Vibration arc generator equipment parameters

设备名称	设备型号
静止电极	5 mm 直径的圆柱形碳棒
移动电极	5 mm 直径的锥形铜棒
音圈电机	OWS80-06-LB-05
光栅传感器	AK-MS15-TTLx20-ZZP1
音圈电机驱动器	ADP-090-09
开关电源	LRS-100-24

1.2 实验方案

为对不同振动频率下电连接器故障电弧特征进行分析,本文利用 1.1 节的实验平台开展振动条件下带变频器三相异步电动机负载电路串联型故障电弧实验。本文设置变频器输出频率为 50 Hz,变频器载波频率为 8 kHz,通过调节摩擦负载使工作电流分别保持在 12 A、13 A、14 A、15 A、16 A,选择振动频率 5、6、⋯、29、30 Hz 进行实验,具体的实验方案如表 2 所示,电流信号采样频率为 50 kHz,并在每组实验中提取 10 个样本,每个样本包含

5 000 个连续时间序列点,即共计 1 300 个样本作为初始样本库。

表 2 实验方案

Table 2 Experimental protocol

实验组号	工作电流/A	电弧	振频/Hz
1~5	12,13,14,15,16	无	0
6~30	12	有	5~30
31~55	13	有	5~30
56~80	14	有	5~30
81~105	15	有	5~30
106~130	16	有	5~30

1.3 实验结果分析

图 3 为表 2 中第 1 组实验的 12 A 实验波形及频谱分析。由于变频器 8 kHz 载波频率的影响,根据正常电流频谱可以看出电流信号中存在载波频率整倍数的高频谐波,导致时域波形存在很大畸变,并存在较多的尖峰突变。




图 3 实验正常波形与频谱

Fig. 3 Experimental normal waveform and frequency spectrum

图 4 所示回路电流为 12 A,在不同振频情况下产生的故障电弧电流波形。由图 4 可知,在音圈电机的作用下,移动、固定电极逐渐分开,随之产生串联型故障电弧,当分开距离较长时,间隙无法被击穿,此时接触点相当于开路状态,电流近似为 0;当移动、固定电极在音圈电机下逐渐靠近时,间隙又被重新击穿,产生故障电弧。因此随着移动电极的往复运动,可以明显看到因振动产生的长时间电流零休现象。从图 4 中不同振频故障波形对比,发现随着振动频率越高,零休时间越短。这是因为随着振频的增加,移动电极往返的时间变短,动静电极间隙更易被击穿,零休时长变短。

在实际工况中,回路电流、振动频率等因素都会影响振动条件下故障电弧的零休时间,这种电流长时间零休现象无法引起断相保护装置动作。同时,三相异步电动机不一定会经历完整的燃弧半周期,无法依据现有电弧故障检测标准设计故障电弧检测装置。综上所述,研究机械振动条件下的工业电机变频器电路串联型故障电弧检测方法是必要的。




图 4 不同振动频率下故障电弧电流分析

Fig. 4 Analysis of fault arc current at different vibration frequencies

2 振动串联故障电弧检测模型

2.1 算法简介

根据上述实验结果可知,振动条件下串联型故障电弧回路电流具有长时间零休现象,因此本文提出构建滑动记忆矩阵方法对电流信号进行动态保存,并通过 OD-LTP 方法提取矩阵的纹理特征,统计两组 OD-LTP 图像的灰度分布直方图数据并串联,得到 18 维特征向量,通过基于沙猫群优化(sand cat swarm optimization,SCSO)的 SVM 检测模型进行分类,实现对振动条件下串联型故障电弧的快速检测。检测模型流程如图 5 所示。




图 5 检测模型流程图

Fig. 5 Flow chart of the detection model

2.2 特征提取方法

1) 构建滑动记忆矩阵

在传统的特征提取方法中,通常选取固定周期的信号,导致数据采集的实时性较差,本文提出通过构建滑动记忆矩阵的方法对时域数据进行动态保存,减少提取的数据量,处理方法如图 6 所示。首先通过滑动窗读取数据,将采集的数据保存至矩阵第 1 行,如图 6 中①所示。当第 1 行数据填充完后将已保存的数据依次向下传递,在第 1 行数据清空后继续进行数据的更新,如图 6 中②

至③过程所示。这样可以在保障实时性的情况下,保留更多的电流信号数据。但滑窗的大小会影响提取数据的实时性与准确度,矩阵的大小会影响计算时间,因此本文在 3.2 节对窗口与矩阵大小的选择进行分析。



图 6 构建滑动记忆矩阵示意图

Fig. 6 Construct a schematic representation of the sliding memory matrix

2) OD-LTP 算法

在常见的纹理特征提取方法中,局部二值化模式(local binary pattern,LBP)类提取方法计算复杂度低,计算简便可以满足检测的实时性要求。局部三值化模式(local ternary pattern,LTP)作为一种 LBP 的广义改进,通过引入阈值 t 来调节 3×3 邻域窗口内中心像素点的上下限,将周围的 8 个点数值分别与中心点上下限进行对比,构成 8 位三进制数,即为该窗口中心点的 LTP 值。对比 LBP,其保留了旋转不变性、灰度不变性等优点,加强了对噪声的鲁棒性,但其特征维度过高,达到 3^8 。

本文提出 OD-LTP 方法来提取纹理特征。根据正交方向将邻域内像素划分为两组,每组分别计算 OD-LTP 代码。OD-LTP 计算示意图如图 7 所示。首先按照数据特征规定 4 个正方向,箭头指向为正方向,通过对比邻域元素 g_i 与邻域均值的 $u \pm t$ 的大小,得到数据梯度方向。当关于中心元素对称的数据梯度方向相同,且都为正时对应的数据编码为 2,都为负时对应的数据编码为 0,当数据梯度方向相反时数据编码为 1。具体的 OD-LTP 计算公式如(1)~(3)所示。




图 7 OD-LTP 计算示意图

Fig. 7 Schematic diagram of the OD-LTP calculation

$$OD-LTP = \sum_{i=1}^{\frac{p}{4}} S_L(g_i, g_{i+\frac{p}{2}}, u, t) \times 3^{i-1} \quad (1)$$

$$S_L(g_i, g_{i+\frac{p}{2}}, u, t) = \begin{cases} 2, & g_i - u \geq t \cap u - g_{i+\frac{p}{2}} \geq t \\ 1, & |g_i - u| \leq t \cup |u - g_{i+\frac{p}{2}}| \leq t \\ 0, & g_i - u \leq -t \cap u - g_{i+\frac{p}{2}} \leq -t \end{cases} \quad (2)$$

$$u = \frac{\sum_{i=0}^P g_i}{P+1} \quad (3)$$

式中: P 代表邻域元素个数, g_0 为中心元素, $g_i, g_{i+\frac{P}{2}}$ 分别代表邻域元素与其中心对称元素, u 代表邻域内所有元素的均值。

本文的特征提取过程如图 8 所示,其中(a)~(d)以 12 A 正常电流信号为研究对象,(e)~(h)以振频 10 Hz 的 12 A 振动串联型故障电流信号为研究对象,并截取故障发生前一周期至故障后半周期数据。在将电流数据构成滑动记忆矩阵后,通过 OD-LTP 算法对滑动记忆矩阵中数据根据梯度方向进行编码,得到两幅 OD-LTP 图像,并统计 OD-LTP 图像的灰度分布直方图数据,将两组直方图进行串联,将得到 18 维直方图幅值作为特征向量。从图 8(a)~(d)中可以看出,正常电流波形在电流波峰波谷处存在少量乱序点,经过本文提取方法后,输出的 OD-LTP 可视化图像的像素点变换间隔均匀且有明显分界线,输出的 18 维直方图中有 4 个维度超过 400,2 个维度超过 100;从图 8(e)~(h)中可以看出,振动故障电弧波形在电流波形前段中谐波增加,导致输出的 OD-LTP 可视化图像的像素噪点变多,且变换间隔不均匀,分界线不明显。在电流波形后段区域,由于存在长时间零休现象,在输出的 OD-LTP 可视化图像中产生较宽的灰色混乱区域,导致 18 维直方图中对应的像素点为 4 和 13 的幅值增加。综上所述,通过 OD-LTP 算法可以有效提取故障数据初步进入滑动记忆矩阵时期的特征。

由于不同的振动条件会导致故障电弧电流波形出现变化,使得 OD-LTP 图像的像素点呈现一定规律,为验证本文方法在不同振动条件下的有效性,截取故障发生前半个周期至故障后一个周期的不同振动频率下的故障电弧电流数据的完整时间序列作为初始信号,通过本文方法对其进行特征提取,对得到的 OD-LTP 可视化图像进行分析,可视化图像如图 9 所示。由图 9 可知,随着振动频率的增加,可视化图像中长零休时间对应的灰色混乱区域逐渐变小,该现象与前文 1.3 节所得结论相符,且依然存在灰色区域使其与正常 OD-LTP 可视化图像有较大区别,验证了 OD-LTP 算法对振动条件下串联型故障电弧特征提取的准确性。

2.3 SCSO-SVM 分类算法

SVM 是一种广义线性分类器,通过监督学习找到一个可以分离事件的最佳分类面,对数据进行二值分类。其与传统的机器学习方法相比,SVM 算法计算复杂度低,其在求解非线性和多维样本分类问题方面具有很大的优势,且实时性好。

在使用 SVM 模型时,惩罚因子 c 决定了对错样本的惩罚力度,核参数 g 决定了核函数的影响范围,这两者

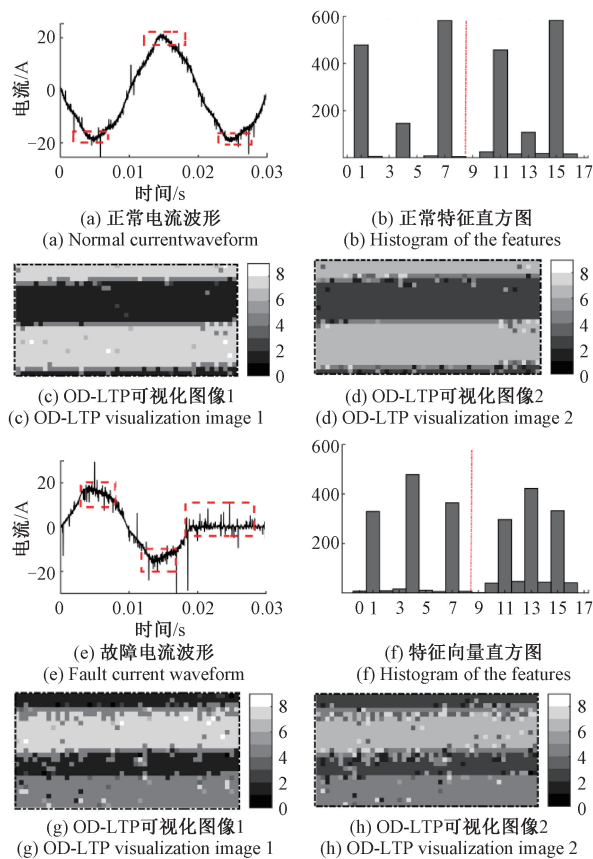


图 8 特征分析例图

Fig. 8 Example diagram of feature analysis

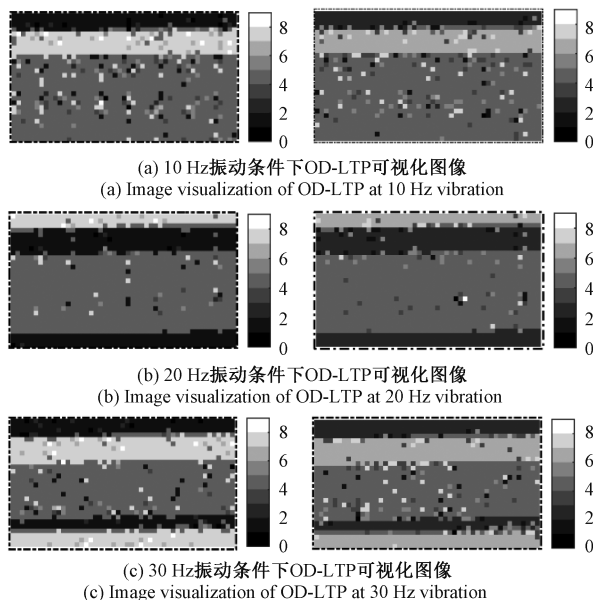


图 9 不同振动条件下 OD-LTP 可视化图像

Fig. 9 Visual images of OD-LTP under different vibration conditions

共同影响了模型的泛化能力。因此需要找到合适的算法对这两个参数进行寻优,使得模型的泛化能力达到最优。

本文选择沙猫群优化算法对 SVM 进行参数优化,并在后文进行对比分析。沙猫群优化算法是一种模仿自然界中沙猫攻击行为和搜寻行为的智能优化算法,基本算法的参数设置如式(4)~(6)所示。

$$r_c = S_M - \left(\frac{S_M \times t}{t_{\max}} \right)$$

(4)

$$R = 2 \times r_c \times rand - r_c$$

(5)

$$r = r_c \times rand$$

(6)

其中, S_M 取 2, t 为当前迭代次数, t_{\max} 为最大迭代次数, r_c 随着迭代次数的增加由 2 线性递减至 0。 R 为选择使用搜索行为或攻击行为的参数。 r 表示每只沙猫的灵敏度范围。 $rand$ 为 0~1 之间的随机数。

$$P_r = rand \times P_{bc}^t - P_c^t$$

(7)

$$P_c^{t+1} = P_c^t - r \times P_r \times \cos(\theta)$$

(8)

$$P_c^{t+1} = r \times (P_{bc}^t - rand \times P_c^t)$$

(9)

攻击行为的数学模型公式如式(7)和(8)所示, P_r 为最优个体附近的一个随机个体, P_{bc}^t 为当前最优个体, P_c^t 为当前迭代个体。 θ 是 $0^\circ \sim 360^\circ$ 之间的随机角度。搜寻行为的数学模型如式(9)所示,新位置在最优个体和当前迭代个体之间,其中灵敏度 r 保证了搜寻行为的收敛效果和复杂度。

3 检测模型优化分析

3.1 阈值选择

本文所提出的 OD-LTP 算法根据阈值 t 来改变邻域均值 u 的数据宽度,减少高频谐波对数据的影响,但 t 的取值会影响后续判断的结果。因此本文统计长时间零休区域电流信号中相邻数据点间的幅值差,寻找 t 的适宜大小。部分幅值差散点图如图 10 所示。结果表明在 0~0.9 范围内的数据占统计数据的 91.8%,同时在后续分析中证明 0.9 为最佳阈值大小。




图 10 相邻误差散点图

Fig. 10 Scatter plot of the adjacent errors

3.2 窗口及矩阵尺寸分析

根据前文分析可知,不同的滑动窗口尺寸影响算法的准确性与实时性,本文需要对滑窗尺寸与矩阵大小进行分析。本文截取采样频率为 50 kHz 的电流信号一个

周期时序数据,即 1 000 个数据点为基准进行初始分析,滑窗尺寸分别选取 24,30,36,42,45,54。为结合数据的采集时间进行综合考虑,本文保留在故障电流数据逐行填充过程中产生的系列矩阵,并将其按照零休时间填充行数分别作为故障样本进行分析。设定当准确率为 95% 以上时,认为电弧故障可以识别;当准确率为 99% 以上时,认为电弧故障完全识别,并将对应的故障数据的填充点数分别命名为 N_1 、 N_2 ,代表着数据填充时间,分析结果如表 3 所示。从表 3 中可知,模型准确度达到可以识别时,滑窗大小为 42 对应的 N_1 最小;模型准确度达到完全识别时,滑窗尺寸为 45 与 36 时对应的 N_2 最小。在考虑 N_1 、 N_2 因素之外,当完全识别故障对应的填充层数较高时,容易导致模型在较低填充层数时发生误判,因此为减少误判概率,填充层数也是影响因素之一。综合以上因素,本文选择 45 作为方法的滑窗尺寸。

表 3 滑窗大小准确度分析

Table 3 Accuracy analysis of the sliding window size

滑窗尺寸	故障数据可以识别 填充点数 N_1	测试准确 率/%	故障数据完全识别 填充点数 N_2	测试准确 率/%
24	$8 \times 24 = 192$	95.3	\	\
30	$5 \times 30 = 150$	95.6	$7 \times 30 = 210$	99.2
36	$4 \times 36 = 144$	97.3	$5 \times 36 = 180$	99.4
42	$4 \times 42 = 126$	95.3	$5 \times 42 = 210$	99.6
45	$3 \times 45 = 135$	97.6	$4 \times 45 = 180$	99.7
48	$3 \times 48 = 144$	98.2	$4 \times 48 = 192$	99.8
54	$3 \times 54 = 162$	98.6	$4 \times 54 = 216$	99.8

由于矩阵的大小影响信息保存和计算速度,需进一步对矩阵的大小进行分析。本文选取滑窗尺寸为 45 对应的可以识别数据样本,对矩阵行数进行依次减少分析,其分析结果如图 11 所示。随着矩阵行数的减少,矩阵包含的数据数量减少,OD-LTP 算法的计算时间减少,但准确度呈现先上升后下降的趋势,在矩阵尺寸为 45×12 时准确度达到 98.6%。因此结合准确率及计算时间,滑动记忆矩阵大小应选择为 45×12 。




图 11 不同矩阵尺寸对比图

Fig. 11 Scatter plot of the adjacent errors

3.3 采样频率对比分析

本文根据采样频率的降低,对窗口尺寸进行等比例缩减使每行数据填充时间一致,例如:当采样频率由

50 kHz 变为 30 kHz 时,窗口尺寸由 45 变为 27。同时将不同填充层数的数据混合训练,对比分析不同采样频率下的准确度与计算速度,识别结果如图 12 所示。随着采样频率的降低,进一步减少了噪声的影响,同时由于矩阵点数降低,加强了计算速度。而 10 与 20 kHz 因为采样点过少,使关键信息丢失过多,易受到谐波影响,导致准确率降低。因此由图 12 可知在不同采样频率下,30 kHz 采样频率及其对应的 27×12 矩阵尺寸为最优。




图 12 不同采样频率对比图

Fig. 12 Scatter plot of the adjacent errors

由于采样频率的改变,可能导致最优矩阵尺寸参数发生变化,同时考虑到窗口参数、矩阵参数与采样频率的潜在耦合因素,因此本文在 30 kHz 采样频率下,以矩阵尺寸为 27×12 为基础,对窗口、矩阵尺寸进行验证,同时选取 40 kHz、20 kHz 的部分窗口尺寸,做进一步对比,部分结果如表 4 所示,其中第 1~9 组对应 30 kHz 采样频率,第 10~13 组对应 40 kHz 采样频率,第 14~15 组对应 20 kHz 采样频率。由表 4 可知,在 30 kHz 采样频率下,所选矩阵尺寸 27×12 为最优,且在 40 kHz、20 kHz 采样频率下的部分尺寸中得到验证。因此在后续分析中使用 30 kHz 作为最终采样频率,同时选择 27×12 为最终滑动记忆矩阵大小。

表 4 不同采样频率、窗口、矩阵尺寸综合对比分析

Table 4 Comprehensive comparative analysis of different sampling frequencies and window matrix sizes

组号	采样频率	矩阵尺寸	准确度/%	数据量
1	30 kHz	24×9	96.1	216
2		24×12	97.4	288
3		24×15	97.3	360
4		27×9	98.3	243
5		27×12	99.2	324
6		27×15	98.7	405
7		30×9	98.7	270
8		30×12	98.9	360
9		30×15	97.8	450
10	40 kHz	36×9	98.6	324
11		36×15	98.1	540
12		39×9	98.7	351
13	20 kHz	39×12	98.5	468
14		18×9	97.6	162
15		18×15	97.2	270

3.4 分类算法对比分析

为验证本文提出优化分类算法的优越性,本文采用模拟退火 (simulated annealing, SA) 算法、遗传算法 (genetic algorithm, GA) 和粒子群优化算法分别对 SVM 进行了优化,并与 SCSO 优化算法进行了比较。SA、GA 和 PSO 分别属于个体启发式算法、进化算法和群体智能算法,设置 SA 的参数长度为 50,SCSO-SVM、GA-SVM 和 PSO-SVM 的最大迭代次数为 100 次,GA-SVM 和 SCSO-SVM 的种群大小为 10 次。参数 *c* 的迭代范围从 0.1~1 000,参数 *g* 的值从 0.1~1 000。在上文窗口矩阵尺寸为 27×12 的样本库中分别随机抽取 500 组训练样本和测试样本,不同类型 SVM 的识别结果如表 5 所示。由表 5 可知,通过 SCSO-SVM 相对于其他优化方法分类准确度最高。

表 5 分类算法分析

Table 5 Analysis of the classification algorithms

方法	准确度/%
PSO-SVM	98.2
SCSO-SVM	99.6
SA-SVM	98.6
GA-SVM	96.4

4 算法在不同实验条件、故障条件下的适用性

4.1 检测模型泛化性分析

由于在不同的工业条件下,三相异步电动机的电路参数也会不同,例如三相异步电机额定频率为 50 或 60 Hz,变频器工作频率可以在 0 Hz 到额定频率之间进行调节,以实现电机转速的控制;对于一个常见的变频器应用,载波频率通常在 6~12 kHz,具体数值会根据需要进行调节以实现最佳的 PWM 控制效果。在之前的分析中,变频器参数为输出频率 50 Hz,载波频率 8 kHz,因此本文将通过改变变频器参数,对检测方法进行泛化性分析,结果如表 6 所示。

表 6 不同工况下检测方法泛化性分析

Table 6 General generalization analysis of detection methods under different working conditions

组号	有无变频器	载波频率/kHz	输出频率/Hz	准确度/%
1	无	\	\	99.6
2	有	6	50	99.4
3	有	8	50	99.2
4	有	10	50	96.3
5	有	12	50	93.4
6	有	8	40	95.4
7	有	8	60	98.8

根据表 6 第 1 组实验可知,无论三相异步电动机是否带变频器运行,都可通过本方法检测由机械振动引发的串联型电弧故障。根据第 2~5 组实验可知,增加变频器载波频率,将引入更多高频噪声,使检测方法准确度降低。当载波频率为 12 kHz 时,谐波过多,波形畸变严重,在实际应用中可以通过滤波元件进行辅助,提高准确度。根据第 3、6、7 组实验可知,当降低变频器输出频率时,回路电流周期发生变化,相对应本算法包含的数据点数也会发生改变,影响了检测方法准确度。综上所述,变频器载波频率为 6~10 kHz 和变频器输出频率为 40~60 Hz 时,本文提出的检测方法都是有效的。

4.2 与其他检测方法对比分析

为了验证所提出的特征提取方法的优越性,以实验所得 30 kHz 采样频率数据为研究对象,使用以下特征提取方法并根据对应参考文献内容处理样本,并与本文所提特征提取方法进行对比分析:

- 1) 文献[3]:对电流信号从时域,频域和小波包能量分析方面多个方向提取特征,构建 24 维特征集,并通过随机森林算法选取关联性最高的 10 个特征;
- 2) 文献[13]:对电流信号进行变分模态分解,并计算所得 8 个信号分量的样本熵与能量作为最终特征向量;
- 3) 文献[12]:使用核主成分分析提取电压信号、故障相电流信号第 5 和 6 个主成分的峰度和偏度作为特征;
- 4) 文献[14]:对电流信号进行小波包分解后,将 32 个频段信号幅值拼接为灰度-梯度共生矩阵,并计算其 15 个特征量作为特征;
- 5) 文献[16]:对电流信号进行 5 层经验小波分解,对每层信号建立步长为 35 的信号延迟矩阵,并将所得 5 个矩阵的前两个奇异值作为串联型故障电弧特征;
- 6) 文献[9]:将电流信号转换为无阈值递归图,并使用 GLCM 提取 21 个图像纹理特征作为串联型故障电弧特征;

将上述方法提取的特征通过 SCSO-SVM 进行分类,训练集与测试集占比为 4:1,分析结果如表 7 所示。方法 1 准确度最高,但其特征提取时间相对于本文算法时间较长。方法 2 使用 2 个周期的电源电压与电流信号进行降维提取特征,数据量多输出特征量少,但准确度最低。方法 3 准确度较高但提取时间过长。方法 4~6 将电流信号转为多维信号进行处理,其中方法 5 的特征提取时间较短,但其在噪声影响下其准确度较低,而其余方法的特征提取时间较长。表 7 表明,本文方法与其他方法对比,所需数据量最少,分类准确度较高,特征提取运算时间最短。同时,本文方法所需数据按照滑动记忆矩阵提取,不同于其他方法固定数据长度,故障数据收集时

间更短。因此本文方法可以很好地实现对振动条件下串联型故障电弧的快速特征提取与检测。

表 7 不同特征提取方法对比
Table 7 Comparison of different feature extraction methods

识别方法	单样本数据量	特征量	样本平均特征提取时间/ms	准确度/%
1	1 200	10	35.8	99.4
2	2 400	4	96.9	84.4
3	1 200	16	87.7	98.8
4	1 200	15	111.6	98.2
5	1 200	10	11.3	97.4
6	1 200	21	437	98.4
本文方法	324	18	1.64	99.2

5 总 结

本文针对振动条件下三相异步电动机变频器负载的串联型故障电弧检测问题,提出了一种具有高实时性的振动条件下故障电弧检测模型。本文采用滑动记忆矩阵的动态信号提取策略,显著提升了回路电流数据处理的效率与实时性;运用 OD-LTP 特征提取方法,有效削弱了回路电流中的高频谐波干扰,同时保证了计算的高效性与精确性;并利用 SCSO 算法优化 SVM 分类器,以提高故障电弧识别的准确率。通过在不同工况下的实验验证,以及与其他检测模型的对比分析,证明本文所提方法在电机变频器类负载故障电弧检测方面的准确性、实时性与通用性。此外,本文方法的低计算成本为微处理器的实时处理提供了有力支持。未来,研究将聚焦于实际电机振动环境下的故障电弧实验及微处理器应用,致力于开发振动条件下电机变频器负载的串联故障电弧检测装置。

参考文献

[1] 唐圣学,刁旭东,陈丽,等. 光伏发电系统直流串联微弱故障电弧检测方法研究 [J]. 仪器仪表学报,2021, 42(3):150-160.
TANG SH X, DIAO X D, CHEN L, et al. Study on detection method of weak series DC fault arc in PV power generation systems [J]. Chinese Journal of Scientific Instrument, 2021, 42(3):150-160.

[2] JIANG R, BAO G H. Series arc fault detection method based on signal-type enumeration and zoom circular convolution algorithm [J]. IEEE Transactions on Industrial Electronics, 2023, 70(10):10607-10617.

[3] JIANG J, LI W, WEN Z, et al. Series arc fault detection based on random forest and deep neural network [J]. IEEE Sensors Journal, 2021, 21(15):17171-17179.

- [4] CAI X R, WAI R J. Intelligent DC arc-fault detection of solar PV power generation system via optimized VMD-based signal processing and PSO-SVM classifier [J]. IEEE Journal of Photovoltaics, 2022, 12 (4): 1058-1077.
- [5] MIAO W C, XU Q, LAN K H, et al. DC arc-fault detection based on empirical mode decomposition of arc signatures and support vector machine [J]. IEEE Sensors Journal, 2021, 21(5):7024-7033.
- [6] 宿磊,沈煜,杨帆,等. 融合 CEEMDAN 分解与敏感 IMF 精选的串联电弧故障检测 [J]. 电子测量与仪器学报, 2022, 36(10):173-180.
- SU L, SHEN Y, YANG F, et al. Series arc fault detection combining CEEMDAN decomposition and sensitive IMF selection [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36 (10): 173-180.
- [7] 张婷,王海淇,张认成,等. 基于自归一化神经网络的电弧故障检测方法 [J]. 仪器仪表学报, 2021, 42(3): 141-149.
- ZHANG T, WANG H Q, ZHANG R CH, et al. An arc fault detection method based on the self-normalized convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2021, 42(3):141-149.
- [8] YIN Z D, WANG L, ZHANG B, et al. An integrated DC series arc fault detection method for different operating conditions [J]. IEEE Transactions on Industrial Electronics, 2021, 68(12):12720-12729.
- [9] FERRACTI F, SCHWEITZER P, MONTERIU A. Arc fault detection and appliances classification in AC home electrical networks using recurrence quantification plots and image analysis [J]. Electric Power Systems Research, 2021, 201:1-12.
- [10] TANG A X, WANG Z Y, TIAN S G, et al. Series arc fault identification method based on lightweight convolutional neural network [J]. IEEE Access, 2024, 12:5851-5863.
- [11] LI W C, LIU Y L, LI Y, et al. Series arc fault diagnosis and line selection method based on recurrent neural network [J] IEEE Access, 2020, 8: 177815-177822.
- [12] HAN C X, WANG Z Y, TANG A X, et al. Recognition method of AC series arc fault characteristics under complicated harmonic conditions [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70:1-9.
- [13] WANG Z Y, HAN C X, GAO H X, et al. Identification of series arc fault occurred in the three-phase motor with

frequency converter load circuit via VMD and entropy-based features [J]. IEEE Sensors Journal, 2022, 22(24):24320-24332.

- [14] 郭凤仪,邓勇,王智勇,等. 基于灰度-梯度共生矩阵的串联故障电弧特征 [J]. 电工技术学报, 2018, 33(1): 71-81.
- GUO F Y, DENG Y, WANG ZH Y, et al. Series arc fault characteristics based on gray level-gradient co-occurrence matrix [J]. Transactions of China Electrotechnical Society, 2018, 33(1): 71-81.
- [15] GAO H X, WANG Z Y, TANG A X, et al. Research on series arc fault detection and phase selection feature extraction method [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-8.
- [16] GAO H X, WANG Z Y, HAN C X, et al. Feature extraction method of series arc fault occurred in three-phase motor with inverter circuit [J]. IEEE Transactions Power Electronics, 2022, 37(9): 11164-11173.
- [17] WANG Z Y, TIAN S G, GAO H X, et al. An on-line detection method and device of series arc fault based on lightweight CNN [J]. IEEE Transactions on Industrial Informatics, 2023, 19(10): 9991-10003.

作者简介



刘艳丽(通信作者), 2004 年于辽宁工程技术大学获得学士学位, 2007 年于辽宁工程技术大学获得硕士学位, 2017 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学副教授, 主要研究方向为电接触理论及其应用、电气故障诊断。

E-mail: liuyanli19810919@163.com

Liu Yanli (Corresponding author) received her B. Sc. degree from Liaoning Technical University in 2004, M. Sc. degree from Liaoning Technical University in 2007 and Ph. D. degree from Liaoning Technical University in 2017, respectively. Now she is an associate professor in Liaoning Technical University. Her main research interests include electrical contact theory and its applications, electrical fault diagnosis.



张凌玮, 2022 年于辽宁工程技术大学获得学士学位。现为辽宁工程技术大学硕士研究生, 主要研究方向为电接触与电弧理论。

E-mail: 1975766122@qq.com

Zhang Lingwei received his B. Sc. degree from Liaoning Technical University in 2022. Now he is a M. Sc. candidate in Liaoning Technical University. His main research interests include electrical contact and arc theory.